

뉴로-퍼지推論 시스템을 이용한 物體認識

正會員 金 亨 根* 正會員 崔 甲 石*

Object Recognition Using Neuro-Fuzzy Inference System

Hyoung Geun Kim*, Kap Seok Choi* *Regular Members*

要 約

本論文은 효과적인 物體認識을 위해 神經回路網의 學習 特性和 퍼지理論의 推論方法을 融合한 것으로서, 神經回路網에 의해 퍼지推論을 자동적으로 實行하는 뉴로-퍼지推論 시스템을 제안하였다.

제안된 뉴로-퍼지推論 시스템은 퍼지 推論規則의 條件部에 해당되는 條件部 神經回路網과 推論規則의 結論部에 해당되는 結論部 神經回路網, 그리고 推論規則의 條件部和 結論部사이의 퍼지關係를 演算하는 퍼지演算部로 이루어진 뉴로-퍼지推論 시스템을 구성하였다. 入力變化에 따른 認識의 曖昧性을 해소하기 위하여, 퍼지推論時 推論規則의 條件部 퍼지命題를 神經回路網의 誤差 逆傳播學習法에 의해 自動生成하므로써, 推論環境의 변화에 따른 퍼지命題에 대한 멤버십函數의 形狀을 適應的으로 변화시켰다. 또한, 條件部 神經回路網을 모델分類用 神經回路網과 線素 分類用 神經回路網으로 분리 구성하므로써, 특징의 유사성 때문에 발생하는 神經回路網의 境界 分離特性的의 한계를 보완할 수 있도록 하여 認識率 低下를 해소하였고, 특히 효과적인 시스템의 출력을 결정하기 위하여 結論部 神經回路網의 出力에 物體認識을 위한 推論規則을 學習시키는 방법을 사용하므로써, 認識率 向上을 도모하였다.

ABSTRACT

In this paper, the neuro-fuzzy inference system for the effective object recognition is studied. The proposed neuro-fuzzy inference system combines learning capability of neural network with inference process of fuzzy theory, and the system executes the fuzzy inference by neural network automatically.

The proposed system consists of the antecedence neural network, the consequent neural network, and the fuzzy operational part. For dissolving the ambiguity of recognition due to input variance in the neuro-fuzzy inference system, the antecedence's fuzzy proposition of the inference rules are automatically produced by error back-propagation learning rule. Therefore, when the fuzzy inference is made, the shape of membership functions is adaptively modified according to the variation. The antecedence neural network constructs a separated MNN(Model Classification Neural

*明知大學校 電子工學科
Dept. of Electronics, Myeongji University.
論文番號 : 92-49(接受1991. 11. 18)

Network) and LNN(Line segment Classification Neural Networks) for dissolving the degradation of recognition rate. The antecedence neural network can overcome the limitation of boundary decision characteristics of neural network due to the similarity of extracted features. The increased recognition rate is gained by the consequent neural network which is designed to learn inference rules for the effective system output.

I. 서론

일반적인 物體認識에 있어서 效果的인 特徵抽出과 柔軟한 物體認識 方法은 다양한 형태의 物體를 融通性있게 認識할 수 있는 物體認識 시스템의 實現을 위해 매우 중요하다. 특히 重複物體 認識시 나타나는 特徵消失現狀은 컴퓨터 비전 응용 및 공장자동화 분야에서 중요한 문제로 대두되고 있다. 그러나 현재까지의 物體認識 方法들은 계산량이 방대하거나, 物體의 크기變換등에 따른 處理效率이 나쁘고, 物體形態의 變形이나 雜音등에 대응하기 곤란하므로 전체적인 認識結果가 좋지 못하는 등의 문제점이 발생하였다.^[1,2]

따라서 이러한 문제점에 효과적이며 柔軟하게 對應될 수 있고, 보다 향상된 認識結果를 얻을 수 있는 物體認識에 관한 연구가 필요하게 되며, 오늘날 物體認識과 같은 패턴認識 分野에의 새로운 接近方法으로써 인간의 情報處理 方式을 도입한 研究들이 다양하게 제시되고 있다.^[3,4]

즉, 인간의 특성을 활성화한 시스템인 神經回路網과 퍼지理論을 이용한 것으로서 神經回路網은 情報의 竝列處理 및 學習機能을 갖고 있으며, 퍼지理論은 max, min이라고 하는 간단한 演算에 의해 情報處理를 하는 計算의 簡便性을 갖고 있는 등의 특징때문에 패턴認識을 비롯한 여러 應用分野에서 활발히 적용되고 있다.^[5,6]

특히, 神經回路網과 퍼지理論이 갖고있는 兩者의 特性을 결합하여 보다 柔軟한 情報處理를 목적으로 하는 研究는 科學技術이 指向하는 목표에 더욱 접근할 수 있는 새로운 방향을 제시할 수 있을 것으로 기대되어 이에 대한 研究가 진행되고 있다. 이러한 兩者의 결합은, 神經回路網에서는 計算의 簡便性을 구하고자 퍼지理論과 결합하고, 퍼지理論에서는 竝列處理와 學習方式에의 발전을 목적으로 神經回路網과 결합을 시도하고 있다. 지금까지 시도되고 있는 結合方法은 크게 神經回路網에 퍼지理論을 도입하는 방법과 퍼지理論에 神經回路網을 도입하는 것으로

나눌 수 있으며,^[7] 최근의 研究動向은 다음 2가지로 나누어 볼 수 있다. 첫째, 일반적인 神經回路網의 結合웨이트(connection weight)를 멤버쉽函數(membership function)로 치환하고, 神經回路網 入力層에 있어서의 入力합을 퍼지理論의 min演算에 대응시키는 方法^[8]과 둘째, 神經回路網과 퍼지推論의 결합으로써, 神經回路網 出力層의 出力結果를 퍼지理論의 멤버쉽函數로 보고 퍼지 推論過程에 적용시키는 방법^[9]으로 나누어 진다.

따라서, 본 論文은 로보트 비전 시스템에 응용할 수 있는 效果的이고 柔軟한 物體認識 方法에 관한 연구으로써 퍼지理論과 神經回路網이 갖고 있는 兩者의 特性을 결합하여 보다 柔軟한 情報處理를 할 수 있는 物體認識시스템에 대해 연구하였다.

II. 뉴로-퍼지推論 시스템

2-1. 뉴로-퍼지推論 시스템의 구성

本 論文에서 物體認識을 위해 제안된 뉴로-퍼지推論 시스템은 神經回路網이 갖고 있는 學習特性과 애매한 情報處理特性을 갖고 있는 퍼지理論의 응용분야인 퍼지推論을 融合한 것으로서, 神經回路網에 의한 퍼지推論을 자동적으로 實現하는 것이다. 즉 퍼지推論을 위해 推論規則의 條件부와 結論부를 神經回路網으로 구성하여 퍼지命題를 자동적으로 生成하므로써, 구성된 神經回路網에 의해 퍼지推論이 이루어지는 神經回路網에 의한 퍼지推論 시스템이 된다. 제안된 시스템은 퍼지推論 規則의 條件부에 해당하는 條件부 神經回路網과 推論規則의 結論부에 해당하는 結論부 神經回路網, 그리고 條件부와 結論부의 퍼지關係를 연산하는 퍼지演算部로 구성되어 있으며, 그 구성도는 그림 1과 같다.

1) 條件부 神經回路網

퍼지推論을 實現하기 위한 推論規則의 條件부에 해당하는 神經回路網으로서, 퍼지推論時 推論規則의 條件부 命題에 대한 멤버쉽函數를 자동生成한다. 條

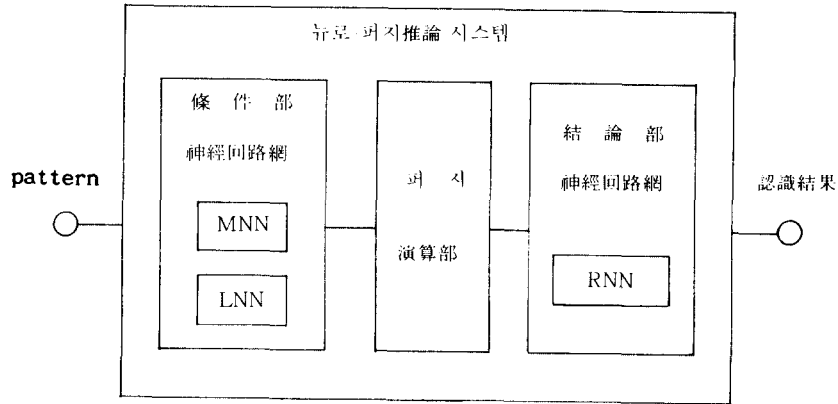


그림 1. 뉴로-퍼지推論시스템의 기본구성
Fig. 1. Structure of neuro-fuzzy inference system.

조건부 신경회로망은 모델 분류용 신경회로망과 선素 분류용 신경회로망으로 구성된다.

① 모델 분류용 신경회로망(MNN: Model classification Neural Network)

入力情報인 局部特徵量으로 부터 認識對象인 모델 單位의 大局의인 情報를 획득하기 위한 神經回路網으로서 모델單位의 멤버쉽函數를 回路網의 出力으로 自動生成한다.

② 線素分類용 神經回路網(LNN: Line classification Neural Network)

모델을 구성하고 있는 局部情報인 線素單位의 情報를 획득하기 위한 神經回路網으로서 線素單位의 멤버쉽函數를 回路網의 出力으로 自動生成한다.

2) 결론부 神經回路網

結論부 神經回路網은 結果判定用 神經回路網(RNN: Result decision Neural Network)으로 구성되어 있다. 最終 認識結果를 判定하는 부분으로서 퍼지推論規則의 結論부에 해당한다.

3) 퍼지演算부

퍼지推論規則의 條件부와 結論부 사이의 퍼지關係를 구하는 부분으로서 條件부 神經回路網과 結論부 神經回路網사이의 퍼지關係를 구하기 위해 퍼지 合成規則인 min演算을 행한다.

2-2. 퍼지推論 알고리즘

제안된 뉴로-퍼지推論 시스템은 神經回路網에 의

해 자동적인 퍼지推論을 실현하는 것으로서, 퍼지推論 과정의 멤버쉽函數의 설정을 條件부에 해당하는 神經回路網의 出力으로서 自動生成하였으며, 結論부 神經回路網의 出力은 推論規則의 學習에 의해 결정하므로서 효과적인 시스템의 出力을 나타내도록 하였다. 퍼지推論 알고리즘은 다음과 같이 세 과정으로 나눌 수 있으며, 세부적으로 살펴보면 다음과 같다.

- ① 條件부 神經回路網을 이용하여 퍼지命題값인 멤버쉽函數의 生成
- ② 퍼지演算부를 이용하여 推論規則의 條件부와 結論부의 퍼지關係表現
- ③ 퍼지關係를 이용하여 結論부 神經回路網으로부터 시스템 出力 결정

1) 멤버쉽 函數의 生成

일반적인 퍼지推論에서는 각 入力變數에 대한 멤버쉽函數를 각 變數에 대해 독립적으로 고정하여 推論하기 때문에 시시각각 변화하는 推論環境에 대해 잘 적응하지 못하는 단점이 생긴다. 이에 대한 해결책으로서 애매함을 표하는 멤버쉽函數를 적응적으로 변화시키는 방법이 제시되고 있다. 즉, 퍼지推論에 있어서 멤버쉽函數의 형상은 施行錯誤로서 조정되는 것이 일반적이나 이것을 神經回路網에 의해 자동적으로 결정함으로써 적응적인 형상변화가 가능하게 된다.^[10] 본 論文에서는 誤差 逆傳播學習을 이용한 클러스터링(clustering)방법에 의해 멤버쉽函數를 자동으로 생성하였다. 즉, 入力變數가 分類하고자 하는 그룹에 속하는 程度를 神經回路網으로 산출하여




그림 2. 멤버쉽函數의 形態決定의 例
Fig. 2. Decision of membership function.

出力結果를 그 그룹에 속하는 歸屬程度인 멤버쉽函數로 하는 神經回路網에 의한 入力 空間上의 퍼지分割 방법이다. 따라서 本 論文中에서 사용된 멤버쉽函數의 形態決定 방법을 예들들어 설명하면, 그림 2와 같다.

먼저 3層의 神經回路網의 入力層에 入力데이터 중의 하나를 $(x_{11}, x_{12}) = (0.2, 0.15)$ 로 하고, $(R_1, R_2, R_3) = (1, 0, 0)$ 로 하여 이들은 각각 入力層의 入力과 出力層의 教師데이터로 주어 誤差 逆傳播學習알고리즘으로 學習을 행한다. 學習이 끝난후, 주어진 데이터(學習데이터)이외의 새로운 未學習데이터를 神經回路網의 入力層에 넣으면, 새로운 데이터에 대한 퍼지集合의 멤버쉽값이 生成된다. 즉, 새로운 데이터 $(x_1, x_2) = (0.5, 0.4)$ 에 대한 멤버쉽값 $(R_1, R_2, R_3) = (0.4, 0.1, 0.2)$ 이 얻어지게 된다.

2) 推論規則의 퍼지關係

퍼지演算部를 이용하여 推論規則의 條件部와 結論部의 퍼지關係를 구하는 과정은 다음과 같다.

먼저 條件部 神經回路網의 出力을 퍼지命題를 나타내는 멤버쉽函數값으로 보고 結論部の 出力을 결정하기 위해 퍼지關係에 근거한 퍼지合成規則^[11]을 적용한다. 즉, 퍼지演算部에 들어오는 條件部 神經回路網 出力인 각 멤버쉽函數값들 사이의 min演算을 행하는 것이다. 예들들면, 모델分類用 神經回路網의 出力 $MNN(R_1, R_2, R_3) = (0.4, 0.1, 0.2)$ 이고, 線素分類用 神經回路網의 出力 $LNN(L_{11}, L_{12}, L_{13}, \dots) = (0.5, 0.8, 0.3, \dots)$ 라면, 퍼지 合成演算式을 이용하여 min을 구하면 推論規則에 의해 $0.4 \wedge 0.5, 0.4 \wedge 0.8, 0.4 \wedge 0.3$ 이므로 $(0.4, 0.4, 0.3, \dots)$ 이 된다. 따라서

구해진 min값이 推論規則의 結論部の 出力을 결정하기 위한 結論部 神經回路網의 入力層의 入力데이터로서 주어지게 된다.

3) 시스템의 出力決定

뉴로-퍼지推論시스템에 있어서 시스템의 最終出力決定은 퍼지關係로부터 推論規則의 結論部를 나타내는 시스템의 結論部 神經回路網의 出力으로써 이루어진다. 즉, 각 推論規則의 結論部の 入出力關係를 다음과 같이 나타낸다.

$$y_i = RNN(x), \quad (1)$$

여기서 y_i 는 i 번째 推論規則에 대한 結論部 神經回路網의 出力을 나타낸다. 또한 식(1)는 結論部 神經回路網 全體의 入出力關係를 나타내는 非線形式이 된다. 이것은 結論部 神經回路網의 誤差 逆傳播學習모델이 入出力데이터의 非線形關係를 나타내고 있기 때문이다.

따라서, 뉴로-퍼지推論 시스템의 最終出力 y^* 는 다음과 같이 구한다.

$$y^* = \max[y_{is}(x_{11}, x_{12}, \dots, x_{1n})] \\ i=1, 2, \dots, n \quad (2)$$

여기서 y_{is} 는 RNN로 부터 구해진 入力데이터 제 i 번째의 出力값을 나타낸다.

Ⅲ. 뉴로-퍼지推論시스템에 의한 物體認識

뉴로-퍼지推論 시스템에 의한 物體認識은 크게 前處理過程과 認識過程으로 나눌 수 있으며, 前處理過程은 物體認識을 위한 特徵抽出과 모델형성으로 이루어지고, 認識過程은 뉴로-퍼지推論시스템에 의해 이루어진다. 物體認識過程의 전체적인 흐름도는 그림 3과 같다.

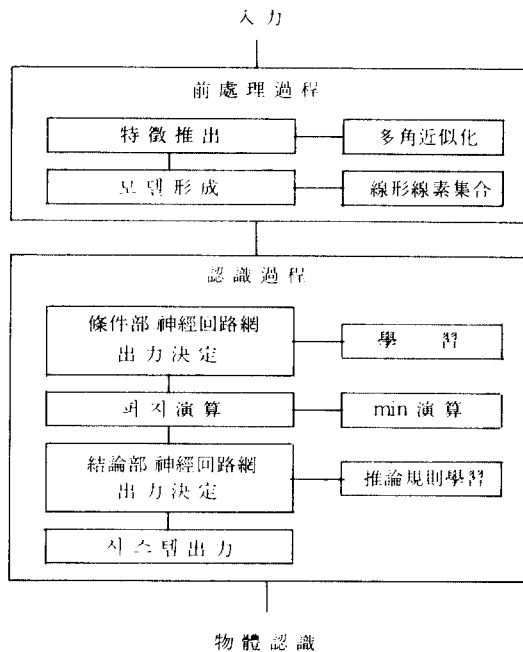


그림 3. 物體認識過程의 흐름도
Fig. 3. Flowchart of object recognition.

3-1. 特徵抽出 및 모델形成

本論文에서 認識을 위해 抽出되는 特徵量은 移動, 回轉 및 位置變化에 무관한 特性을 갖는 不變特徵量을 사용한다. 特徵集合의 요소로서의 線形線素는 物體의 境界點으로부터 抽出된 局部特徵點으로 구성된다. 즉, 境界檢出過程을 기친 映像에서 物體의 境界點들은 多角形近似化에 의해 여러개의 線形線素로 분리되며 모델 및 未知映像은 線形線素의 集合으로 변환된다. 따라서 物體를 효과적으로 記述하기 위해 사용된 線形線素의 特徵量은 式(3)와 같이 정의되며, 그림 4와 같다.

$$\begin{aligned}
 \text{Seg} &= (\theta, l, \theta', l', R\theta, Rl) & (3) \\
 \theta &: \angle P_{n-1}, P_n, P_{n+1} \\
 l &: l(P_{n-1}, P_n) + l(P_n, P_{n+1}) \\
 \theta' &: \angle P_{n-2}, P_n, P_{n+2} \\
 l' &: l(P_{n-2}, P_n) + l(P_n, P_{n+2}) \\
 R\theta &: \theta / \theta' \\
 Rl &: l / l'
 \end{aligned}$$

여기서 P_n 은 多角近似화된 物體에 있어서 n 번째 屈曲點을 나타내고, $\theta, \theta', R\theta$ 는 線形線素 사이의 角度情報를 나타내며, l, l', Rl 은 線形線素의 사이의 距離情報를 나타낸다. 이러한 線形線素의 抽出은 부분적인 境界點들을 直線으로 近似化함으로써 이루어진다.




그림 4. 特徵量의 定義
Fig. 4. Definition of features.

따라서 모델映像은 多角近似化에 의해 局部特徵값이 포함된 線形線素들의 集合으로 모델링되고, 새로 入力되는 未知映像 역시 동일과정을 거쳐 線形線素들의 集合으로 모델링되어 모델과 未知映像의 線形線素들간의 매칭에 의해 類似性을 측정하므로써 未知映像 내의 모델을 認識하게 된다.

3-2. 物體認識 알고리즘

物體認識을 위한 全體過程中 認識過程은 뉴로-퍼지推論시스템에 의해 이루어지며, 사용된 뉴로-퍼지推論시스템의 細部構成圖는 그림 5와 같다.

뉴로-퍼지推論 시스템을 이용한 物體認識 알고리즘은 크게 ① 條件部神經回路網의 出力決定過程과 ② 結論部神經回路網의 出力決定過程으로 나누어진다.




그림 5. 뉴로 퍼지 추론 시스템의 細部 構成圖
Fig. 5. Detailed structure of neuro-fuzzy inference system.

1) 條件部 神經回路網의 出力決定

條件部 神經回路網의 出力決定은 條件部 神經回路網을 이용하여 未知映像의 特徵量에 대한 멤버십函數의 형태를 決定하는 것으로서, 다음과 같이 이루어진다. 먼저 物體 認識을 위한 퍼지 추론 規則은 다음과 같다.

規則 I : if $x_i = (\theta, l, \theta', l', R\theta, Rl) \text{ belongs to } M_s$ and $x_i = (\theta, l, \theta', l', R\theta, Rl) \text{ belongs to } L_{si}$
then $y = M_s$ and $y_i = L_{si}$
 $i = 1, 2, \dots, N, s = 1, 2, \dots, M \quad N > M$

여기서 M_s 는 s번째의 모델을 나타내며, L_{si} 는 s번 모델중의 제 i번째의 線形線素를 나타내고, $\theta, l, \theta', l', R\theta, Rl$ 는 각각 i번째 線形線素를 구성하는 局部 特徵量을 나타낸다.

따라서 추론規則中的 條件部에 대한 퍼지命題값인 멤버십函數를 自動生成하기 위해서 條件部 神經回路網을 이용한다. 本 시스템에서의 條件部 神經回路網은 각각 모델 分類用과 線素分類用 神經回路網으로 나누어진다. 이것은 物體 認識을 위해 사용되는 線形

線素에 대한 局部 特徵量을 이용하여 物體를 認識할 경우, 발생하는 認識의 애매성을 最小化 하기 위해 모델單位의 大局的인 情報를 나타낼 수 있는 모델 分類用 神經回路網과 線素單位의 局部的인 情報를 함유하고 있는 線素分類用 神經回路網으로 나누어 구성하였으며, 이 두개의 神經回路網에 의해 분류될 수 있는 特徵의 境界分離 能力의 한계를 相互補完 할 수 있도록 하였다. 따라서 추론規則에 있어서 條件部를 구성하는 추론規則은 두개로 나누어진다. 즉, 모델 分類用 神經回路網을 위한 추론規則에서 분류하려고 하는 分割數 M_s 가 모델 數와 같으므로 모델 1, 2, 3의 3개가 되고, 線素分類用 神經回路網의 分割數는 각 모델을 구성하고 있는 線素數가 되므로 각각 18, 15, 16개가 되어 각 추론規則은 각각의 分割數에 의해 이루어지므로 條件部를 구성하는 추론規則은 全體 49개의 規則으로 이루어진다.

따라서, 條件部 神經回路網에 의한 멤버십函數의 自動生成過程을 살펴 보기 위해 條件部 神經回路網의 入力層에 주어지는 데이터의 예를 表1에 나타내었으며, 條件部를 구성하고 있는 두개의 神經回路網에 대해 나누어 살펴보면 다음과 같다.

表 1. 條件部 神經回路網의 入力데이터
Table 1. Input data of IF part neural network.

| 모 델 | 特 徵 量 | 線 形 線 素 | | | |
|-----|-----------|---------|---------|-----|---------|
| | | 1 | 2 | ... | n |
| 모델1 | θ | 0.02728 | 0.03953 | . | 0.10846 |
| | l | 0.85113 | 0.93822 | . | 0.11448 |
| | θ' | 0.04876 | 0.77635 | . | 0.37979 |
| | l' | 0.04868 | 0.51065 | . | 0.96363 |
| | $R\theta$ | 0.01378 | 0.82083 | . | 0.41037 |
| 모델2 | θ | 0.32162 | 0.14465 | . | 0.06293 |
| | θ | 0.09340 | 0.21160 | . | 0.09767 |
| | l | 0.68198 | 0.41403 | . | 0.23158 |
| | θ' | 1.00000 | 0.14465 | . | 0.32538 |
| | l' | 0.13799 | 0.34635 | . | 0.56156 |
| 모델3 | $R\theta$ | 0.11599 | 0.42294 | . | 0.54758 |
| | Rl | 0.09017 | 0.32691 | . | 0.17426 |
| | θ | 0.88902 | 0.07099 | . | 0.11448 |
| | l | 0.47144 | 0.17023 | . | 0.60342 |
| | θ' | 0.05862 | 0.41622 | . | 0.84223 |
| 모델3 | l' | 0.15966 | 0.58636 | . | 0.49897 |
| | $R\theta$ | 0.27968 | 0.42758 | . | 0.05374 |
| 모델3 | Rl | 0.12484 | 0.29907 | . | 0.31140 |

먼저 모델 分類用 神經回路網을 이용한 멤버쉽函數의 자동生成을 살펴보면, 모델分類에 관계되는 推論規則의 條件部는 다음과 같다.

- 규칙 1 : if $x_i = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to M_1
- 규칙 2 : if $x_i = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to M_2
- 규칙 3 : if $x_i = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to M_3

따라서 모델 分類用 神經回路網의 入力層에 주어지는 入力데이터中의 하나를 $x_i = (0.02, 0.85, 0.04, 0.04, 0.13, 0.32)$ 로 하고, 분류하고자 하는 모델은 $(M_1, M_2, M_3) = (1, 0, 0)$ 로 하여 誤差 逆傳播學習알고리즘에 의해 學習한 후 學習데이터 이외의 未知映像에 대한 데이터를 神經回路網의 入力層에 넣으면 새로운 데이터가 모델中에 속하는 程度를 出力層에서 나타나게 된다. 즉, 새로운 데이터에 대한 모델의 歸屬程度인 멤버쉽값이 구해진다. 구해진 멤버쉽값의 예를 表2에 나타내었다.

表 2. 모델分類用 神經回路網의 入力 데이터와 生成된 멤버쉽값.

Table 2. Input-output data and membership values of MNN.

| 모델 | 入 力 데이터 | | | | | | 教師데이터 | | | 生成된 멤버쉽값 |
|----|----------|------|-----------|------|-----------|--------|-------|-------|-------|----------------|
| | θ | l | θ' | l' | $R\theta$ | Rl_1 | M_1 | M_2 | M_3 | |
| 1 | 0.02 | 0.85 | 0.04 | 0.04 | 0.13 | 0.32 | 1 | 0 | 0 | 0.98 0.01 0.02 |
| | ⋮ | | | | | | ⋮ | | | ⋮ |
| 2 | 0.09 | 0.68 | 1.00 | 0.13 | 0.11 | 0.09 | 0 | 1 | 0 | 0.10 0.89 0.04 |
| | ⋮ | | | | | | ⋮ | | | ⋮ |
| 3 | 0.88 | 0.47 | 0.05 | 0.15 | 0.27 | 0.12 | 0 | 0 | 1 | 0.01 0.20 0.90 |
| | ⋮ | | | | | | ⋮ | | | ⋮ |

또한, 線素分類用 神經回路網에 있어서의 멤버쉽函數의 生成은 모델 分類用 神經回路網과 같이 유사하게 이루어지며, 사용된 推論規則의 條件部는 다음과 같다.

- 규칙 1 : if $x_1 = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to L_{s1}
- 규칙 1 : if $x_2 = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to L_{s2}
- ⋮
- 규칙 I : if $x_i = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to L_{si}

線素分類用 神經回路網에 있어서 주어지는 入力 데이터와 學習이 끝난 후 구해진 未知映像에 대한 멤버쉽函數값의 예를 表3에 나타내었다.

表 3. 線素 分類用 神經回路網의 入力 데이터와 生成된 멤버쉽값.

Table 3. Input-output data and membership values of LNN.

| 線素 | 입 력 데이터 | | | | | | 教師데이터 | | | 生成된 멤버쉽값 | |
|----|----------|------|-----------|------|-----------|--------|-------|-------|-------|-----------|------|
| | θ | l | θ' | l' | $R\theta$ | Rl_1 | L_1 | L_2 | L_n | | |
| 1 | 0.02 | 0.85 | 0.04 | 0.04 | 0.13 | 0.32 | 1 | 0 | 0 | 0.98 0.02 | 0.01 |
| 2 | 0.03 | 0.93 | 0.77 | 0.51 | 0.82 | 0.14 | 0 | 1 | 0 | 0.10 0.89 | 0.04 |
| ⋮ | ⋮ | | | | | | ⋮ | | | ⋮ | |
| n | 0.10 | 0.11 | 0.37 | 0.96 | 0.41 | 0.06 | 0 | 0 | 1 | 0.02 0.04 | 0.80 |

2) 結論部 神經回路網의 出力決定

結論部 神經回路網의 出力決定은 推論規則의 條件部와 結論부의 퍼지關係로써 이루어진다. 本 論文에서는 推論環境에 보다 유연히 대응할 수 있고, 認識의 애매성을 해소하기 위해 結論部 神經回路網의 出力決定은 推論規則을 學習시키는 것으로 實現하였다. 즉, 結論部 神經回路網의 入力로 들어온 條件部 神經回路網의 出力데이터에 대한 結論部 神經回路網의 出力은 結論部 神經回路網에 推論規則을 學習시키므로써 結論部 神經回路網의 出力이 결정되며, 구체적으로 살펴보면 다음과 같다. 物體認識 능률 퍼지推論 시스템에 사용된 推論規則은 다음과 같으며, 이 推論規則을 結論部 神經回路網의 出力으로 學習시킨다.

- 規則 1 : if $x_i = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to M_1 and $x_1 = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to L_{11} then $y = M_1$ and $y_1 = L_{11}$
- 規則 2 : if $x_i = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to M_1 and $x_2 = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to L_{12} then $y = M_1$ and $y_2 = L_{12}$
- ⋮
- 規則19: if $x_i = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to M_2 and $x_1 = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to L_{21} then $y = M_2$ and $y_1 = L_{21}$
- 規則20: if $x_i = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to M_2 and $x_2 = (\theta, l, \theta', l', R\theta, Rl_1)$ belongs to L_{22}

∴ then $y = M_2$ and $y_2 = L_{22}$ ∴
 ∴ ∴ ∴
 規則34:if $x_i = (\theta, 1, \theta', 1', R\theta, R1')$ belongs to M_3 and
 $x_1 = (\theta, 1, \theta', 1', R\theta, R1')$ belongs to L_{31}
 then $y = M_3$ and $y_1 = L_{31}$
 規則35:if $x_i = (\theta, 1, \theta', 1', R\theta, R1')$ belongs to M_3 and
 $x_1 = (\theta, 1, \theta', 1', R\theta, R1')$ belongs to L_{32}
 then $y = M_3$ and $y_2 = L_{32}$ ∴
 ∴ ∴ ∴

즉, 條件部 神經回路網의 출력으로 산출된 推論規則의 퍼지命題들은 퍼지演算에 의해 條件부와 結論部の 퍼지關係를 나타내며, 퍼지關係에 의거하여 結論部 神經回路網의 出力을 결정하기 위해 推論規則을 結論部 神經回路網에 學習시키는 것이다. 그림 6에 結論部 神經回路網에 學習되는 推論規則의 因果關係를 圖示하였으며, 그림중 結論部 神經回路網 出力에서 위에서 부터 세개의 유니트는 모델 情報를 나타내며, 나머지 18개의 유니트는 각 모델에 대한 線素情報를 나타낸다.




그림 6. 學習 推論規則의 因果關係.
 Fig. 6. Causal relation of learned inference rules.

실제적으로 誤差 逆傳播學習法에 의한 推論規則의 學習時 사용되는 結論部 神經回路網의 教師데이터는 表 4와 같다. 따라서 結論部 神經回路網의 入力으로 未知데이터가 주어지면 學習된 推論規則에 의해 結論部 神經回路

表 4. 結論部 神經回路網의 教師데이터
 Table 4. Target data of THEN part neural neural network.

| 추론 규칙 | 교사 데이터 |
|-------|--------------------|
| 규칙 1 | 100 100 . . . 0000 |
| 규칙 2 | 100 010 . . . 0000 |
| ∴ | ∴ ∴ ∴ |
| 규칙 18 | 100 000 . . . 0001 |
| 규칙 19 | 010 100 . . . 0000 |
| 규칙 20 | 010 010 . . . 0000 |
| ∴ | ∴ ∴ ∴ |
| 규칙 33 | 010 000 . . . 0001 |
| 규칙 34 | 001 100 . . . 0000 |
| 규칙 35 | 001 010 . . . 0000 |
| ∴ | ∴ ∴ ∴ |
| 규칙 49 | 001 000 . . . 0100 |

網의 出力을 결정하게 된다. 결국, 뉴로-퍼지推論 시스템의 最終出力은 구해진 結論部 神經回路網의 모델 單位의 出力과 線素單位의 出力에서 각각의 max 값을 最終出力으로 한다.

IV. 實驗 및 考察

4-1. 實驗

認識實驗을 위한 映像의 入力은 그림자 및 物體表面의 反射와 같은 雜音의 影響을 허용 하기 위해 自然照明下에서 받아들여졌으며, 實驗은 Intel 80386 CPU에 80387 coprocessor가 장착된 IBM PC-AT 호환기종에서 C언어로 수행되었다. 本 論文에서의 物體認識은 單獨 物體認識과 重複物體認識으로 나누어 실험하였으며, 物體認識時 物體의 變形에 따른 認識結果를 알아보기 위해 크기 및 形態 變形과 크기와 형태변형이 동시에 일어난 未知映像에 대해서도 실험하였다. 實驗에 사용된 3개의 모델映像은 프라이어, 가위 및 스패너와 같은 공구로서 256×256 畫素 크기로 구성되었다. 구성된 모델映像에 대해 物體의 境界를 抽出한 후 線形線素들의 集合으로 近似化 한 다.

實驗에서 사용된 未知映像은 540개의 모델이 포함된 240개의 映像이며, 이 中 單獨모델映像이 40개, 2개의 모델과 3개의 모델이 重複된 映像이 각각 100개 씩이다. 또한, 240개의 未知映像中 120개의 映像은 對象物體가 變形되지 않은 映像이고, 나머지 120개의

未知映像은 對象物體의 크기 및 形態의 變形이 일어난 映像이다.

4-2. 실험방법


本 論文에서는 뉴로-퍼지推論 시스템에 의한 物體 認識 方法의 타당성을 알아보기 위하여, 神經回路網에 의한 방법[1]과 퍼지推論에 의한 방법[12], 그리고 뉴로-퍼지推論 시스템에 의한 방법으로 나누어 각각의 實驗을 통해 그 結果를 比較, 考察하였으며, 각각의 방법이 적용된 物體認識 實驗은 單獨物體와 重複物體로 나누어 수행되었다.

뉴로-퍼지推論 시스템에 의한 방법을 살펴보면, 시스템中的 神經回路網 構成과 구성된 回路網 유니트는 다음과 같다.


- MNN : 入力層 : 6개
 中間層 : 10개
 出力層 : 3개
- LNN1 : 入力層:6개 LNN2: 入力層:6개 LNN3: 入力層:6개
 中間層:10개 中間層:10개 中間層:10개
 出力層:18개 出力層:15개 出力層:16개
- RNN : 入力層49개
 中間層 : 20개
 出力層 : 21개

구성된 條件部 神經回路網과 結論部 神經回路網은 모두 誤差 逆傳播學習 알고리즘을 이용하여 學習하였고, 條件部 神經回路網中 MNN은 總誤차가 0.001에 수렴하도록 學習시켰으며, LNN은 總誤차가 0.01, 그리고 RNN은 0.0001에 도달하도록 學習시켰고, 모두 慣性率 0.9, 學習率 0.1로 하였다. 퍼지推論을 實現하기 위한 멤버십函數의 生成은 神經回路網에 의해 자동으로 生成되며, 주어진 教師데이터에 의해 學習된 條件部 神經回路網에 入力데이터가 주어지면 推論規則의 條件部 퍼지命題가 모델分類用 神經回路網과 線素分類用 神經回路網의 出力으로 각각 산출되며, 條件部 神經回路網의 出力을 조정하기 위한 퍼지演算部에 들어가게 된다. 퍼지演算部로 들어온 데이터는 퍼지關係의 合成演算規則에 의해 min演算이 이루어지며, 演算結果는 結論部 神經回路網의 入力層으로 제시된다. 結論部 神經回路網의 入力層에 제시된 入力데이터는 學習된 推論規則에 따라 結論部 神經回路網의 出力層 유니트로 전달되며, 出力된 결과들의 max演算에 의해 뉴로-퍼지推論 시스템의 最終出力을 나타나게 된다. 뉴로-퍼지推論 시스템의 각


神經回路網에 대한 收斂特性을 그림 7에 學習횟수 對 誤差와의 관계로써 나타내었다.



(a)




(b)



(c)



(d)



(e)

그림 7. 뉴로-퍼지推論 시스템의 神經回路網에 대한 收斂特性

Fig. 7. Convergence characteristics of neural network in neuro-fuzzy inference system.

(a) MNN (b) LNN1 (c) LNN2 (d) LNN3 (e) RNN.

4-3. 認識結果

本 論文에서 認識結果에 대한 모델의 認識與否의 判定은 線素認識率이 50% 이상인 것을 모델判定의 對象으로 하였으며, 對象中 다시 認識된 線素數가 原

모델映像 線素數의 50% 이상의 것을 모델에 대한 正認識으로 하였다. 즉, 線素의 認識率은 다음과 같이 正義하고,

$$\text{線素認識率} = \frac{\text{모델범위내에 존재하는 正認識 線素數}}{\text{모델범위내에 존재하는 線素數}}$$

여기서 모델이 위치한 범위밖에 나타난 認識結果는 무시하였다. 또한 線素의 認識率 50% 를 기준으로 하므로써 발생하는 認識判定의 不合理性을 보완하기 위해 線素의 正認識率이 50% 이상인 것만을 對象으로 하여, 對象中 正認識 線素數가 原 모델映像의 線素數의 50% 이상의 것을 모델에 대한 正認識, 50% 이하의 것을 誤認識으로 하여 最終 모델의 認識與否를 判定하는 방법을 택하였다. 즉, 認識結果 그림中에 표시된 '.'은 線刑線素들 사이의 매칭에 의해 認識對象모델을 認識한 결과를 나타내는 點(dot)이며,

認識된 線素에 대한 꼭지점을 표시하고 있으므로, '.'의 갯수를 기준으로 하여 認識結果에서 認識對象 모델이 위치한 범위안에 표시된 '.'의 갯수를 線刑線素

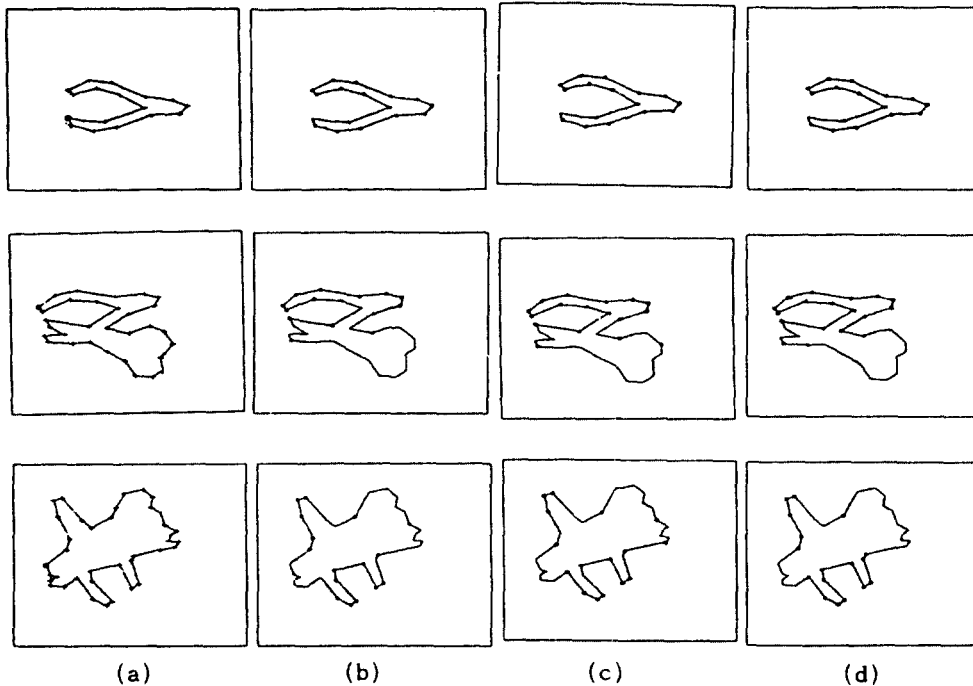


그림 8. 認識結果(認識對象 : 프라이어)

Fig. 8. Recognition results(plier).

(a) polygonal approximation (b) neural network (c) fuzzy inference (d) neuro-fuzzy inference

의 正認識갯수로 하고, 認識對象모델의 범위안에서 ‘·’로 표시된 點을 제외한 나머지 갯수를 誤認識 갯수로 하였으며, 또한 對象모델의 범위를 벗어난 위치에 나타난 결과와, 對象모델과 다른 모델과의 重複에 의해 나타난 境界點들은 무시하였다. 그림 8은 實驗을 통해 나타난 認識結果의 例를 나타내었다. 그림중 (a)는 多角近似化 結果를 나타내며, 그림(b), (c), (d)는 각각 神經回路網에 의한 實驗, 퍼지推論에 의한 實驗 그리고 뉴로-퍼지推論 시스템에 의한 實驗을 통해 나타난 認識結果들로서 單獨 및 重複된 映像에 있어서 프라이어 모델에 대한 결과들이다.

4-4. 結果考察

實驗을 통하여 나타난 認識結果를 比較, 檢討하기 위하여 本論文에서는 單獨 및 重複物體인 경우와 物體가 變形되었을 경우, 그리고 物體의 重複程度로 나누어 각각 神經回路網 및 퍼지推論, 그리고 뉴로-퍼지推論 시스템에 의한 방법이 적용된 結果를 比較, 檢討하였다.

單獨 및 重複된 경우의 入力映像에 대한 각 實驗方法別 線素의 認識率 變化를 살펴보면 뉴로-퍼지推論 시스템에 의한 방법이 다른 두 방법에 비해 重複된 映像에 있어서 훨씬 향상된 認識結果를 보이고 있다. (그림 9)

또한, 認識對象 物體가 각각 크기가 變形된 경우와 形態가 變形된 경우 그리고 크기 및 形態가 동시에 變形된 경우에 대한 認識結果(그림 10)와 物體가 變形된 경우 入力映像에 따른 각 實驗方法에 대한 線素의 認識結果를 나타내었으며(그림 11), 특히 物體 變形시 重複物體인 경우에서 뉴로-퍼지推論 시스템에 의한 방법이 월등한 認識結果를 보이고 있다.

表 5에 物體의 重複程度에 따른 認識結果를 나타내었으며, 表에서 物體의 重複度는 30%의 線素重複을 基準으로 하였으며, 30% 이상의 重複度라는 것은 보이는 부분이 70% 이하를 의미하고, 30%이하의 重複度라는 것은 70% 이상이 보이고 있음을 의미한다. 物體의 重複度는 正認識 線素 數와 誤認識 線素 數를 합한 갯수와 原 모델映像의 線素數와의 比로서 정의하였다. 表에서 살펴보면, 뉴로-퍼지推論 시스템이 다른방법에 비해 認識性能이 상당히 개선됨을 확인할 수 있다. 즉, 30% 이상으로 심하게 重複된 경우 전체적인 認識率은 낮으나, 認識率의 向上側面에서 살펴보면 뉴로-퍼지推論 시스템에 의한 방법이 다른

두 방법에 비해 약 8~10%의 認識率 向上을 보이고 있다.

V. 結 論

本論文은 효과적인 物體認識을 위해 神經回路網과 퍼지推論이 融合된 뉴로-퍼지推論 시스템을 제안하였으며, 物體認識에 적용된 實驗結果를 종합 검토한 결과, 뉴로-퍼지推論 시스템에 의한 認識方法이




그림 9. 入力映像에 따른 線素의 認識率
Fig. 9. Recognition rate of segments according to input image.




그림 10. 物體變形에 따른 認識率
Fig. 10. Recognition rate according to variation.




그림 11. 入力映像에 따른 線素의 認識率
 Fig. 11. Recognition rate of segments according to input image.

表 5. 物體重複度에 따른 認識結果
 Fig. 5. Recognition: results according to occlusion degree.

| 重複度 | 方法映像 | 神經回路網 | 퍼지推論 | 뉴로퍼지推論시스템 |
|-------|------|-------|------|-----------|
| 30%이하 | 2개重復 | 96 | 97 | 98 |
| | 3개重復 | 93 | 92 | 95 |
| 30%이상 | 2개重復 | 80 | 78 | 88 |
| | 3개重復 | 75 | 76 | 86 |

神經回路網이나 퍼지推論에 의한 認識方法에 비해 全體적으로 높은 認識率을 나타내므로써 效果的인 物體認識 方法임을 확인하였다. 또한, 뉴로-퍼지推論 시스템에 있어서 條件部 神經回路網을 모델 分類用 神經回路網과 線素分類用 神經回路網으로 分離 構成 하고, 結論部 神經回路網의 出力을 推論規則의 學習에 의해 결정하는 시스템 構成은 特徵의 類似性으로 인한 認識率의 低下問題의 해소가 가능하였다. 그리고, 物體의 變形과 같은 入力の 變動에 따른 認識의 曖昧性은 퍼지推論時 推論規則의 퍼지命題에 대한 멤버쉽函數를 神經回路網에 의해 自動生成되므로 자연 해소되고, 推論環境의 變化에 대해서도 適應의이 되는 등의 장점이 있다.

參 考 文 獻

1. B. Bhanu et al, "Recognition of occluded objects: A cluster-structure algorithm," Pattern Recognition, vol.20, No.2, pp.199-211, 1987.
2. W.S.Rutkowski, "Recognition of occluded shapes using relaxation," Computer Graphics, Image Processing, vol.19, pp.111-128, 1982.
3. C.Von der Malsburg, "Pattern recognition by labeled graph matching," Neural Networks, vol.1, pp.141-148, 1988.
4. T.L.Huntsberger, C.L.Jacobs, and R. L. Cannon, "Iterative fuzzy image segmentation," Pattern Recognition, vol.18, no.2, pp.131-138, 1985.
5. G.A.Carpenter, "Neural network models for pattern recognition and Associative memory," Neural Networks, vol.2, pp.243-257, 1989.
6. A.Kandel, Fuzzy techniques in patteern recognition, John Wiley&Sons, Inc. 1982.
7. H.Taragi, "Fusion technology of fuzzy theory and neural networks survey and future directions," Proceedings of ICFNN, pp.13-26, 1990.
8. W.Pedrycz, "Fuzzy sets and neurocomputations foundations of pattern recognition," Tutorial of ICFNN, pp.89-120, 1990.
9. T.Iwata et al, "Fuzzy control using neural network techniques," Proc. of IJCNN, vol.3, pp/365-370, 1990.
10. 藤岡亮介 外, "ニューラルネットワークによるメソバシッブ關數の同定," 信學論 D-II, vol. J73D-II, No.8, pp.1227-1232, 1990.
11. 本多中二, 中里有生, ファジイ工學入門, 海文堂.
12. 최갑석, 김형근외, "신경회로망과 퍼지추론을 이용한 중복물체인식의 비교," 韓國通信學習 學術大會 論文集, vol.10, No.2, pp.190-193, 1991.
13. 최갑석, 김형근외, "Fuzzy 추론에 의한 중복물체 인식," 韓國通信學習 論文誌, vol.16, No.1, pp. 23-34, 1991.



金亨根(Hyoung Geun Kim) 正會員
1958年 4月 12日生
제17권 3호 참조



崔甲石(Kap Seok Choi) 正會員
1930年 9月 30日生
제17권 3호 참조